



Klasifikasi Penyakit pada Daun Padi Menggunakan Teknik Pengolahan Citra dan *Convolutional Neural Network*

Firman Putra Perdana^{1*}, Bambang Irawan², Otong Saeful Bachri³

¹⁻³Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muahdi Setiabudi, Indonesia

Email: firmanputraperdana03@gmail.com^{1*}, bambangumus@gmail.com², otongsb@umus.ac.id³

*Penulis Korespondensi: firmanputraperdana03@umus.ac.id

Abstract. Rice cultivation plays a crucial role in national food security, but is often hampered by leaf disease attacks that significantly impact production decline. To address this challenge, this study designed an application based on the Convolutional Neural Network (CNN) algorithm to classify rice leaf diseases automatically and accurately. Data collection was conducted through direct observation at Gapoktan (Farmer Group Association) in Kuningan Regency, interviews with farmers, literature studies, and system development using the Rapid Application Development (RAD) approach, which enables rapid and structured application development. The CNN model was tested using 480 sample images and achieved a high accuracy of 97.75%. The F1-Score values obtained were 0.97 for Brown Spot, 0.921 for Blast, 0.871 for Hispa, and 0.952 for healthy leaves. These results indicate that the application is capable of early disease detection, enabling farmers to take immediate preventive measures to minimize crop losses. To improve performance, it is recommended to apply optimization techniques to the CNN model, such as dataset expansion, various dataset augmentation techniques, and evaluation of high-complexity images. Development into other disease classifications is also highly potential. Overall, this application has significant potential to support digital agriculture and realize a more sustainable and modern rice farming system.

Keywords: Accuracy; Agriculture; Classification; CNN; Rice_Leaf_Image.

Abstrak. Budidaya padi memegang peranan penting dalam ketahanan pangan nasional, namun sering terhambat oleh serangan penyakit daun yang berdampak signifikan terhadap penurunan produksi. Untuk menjawab tantangan tersebut, penelitian ini merancang sebuah aplikasi berbasis algoritma *Convolutional Neural Network* (CNN) guna mengklasifikasi penyakit daun padi secara otomatis dan akurat. Pengumpulan data dilakukan melalui observasi langsung di Gapoktan (Gabungan Kelompok Tani) Kabupaten Kuningan, wawancara dengan petani, studi literatur, serta pengembangan sistem menggunakan pendekatan Rapid Application Development (RAD) yang memungkinkan pembangunan aplikasi secara cepat dan terstruktur. Model CNN yang dibangun diuji menggunakan 480 gambar sampel dan menghasilkan akurasi tinggi sebesar 97,75%. Nilai F1-Score yang diperoleh yaitu 0,97 untuk Brown Spot, 0,921 untuk Blast, 0,871 untuk Hispa, dan 0,952 untuk daun sehat. Hasil ini menunjukkan bahwa aplikasi mampu mendeteksi penyakit secara dini, sehingga petani dapat segera mengambil tindakan preventif untuk meminimalkan kerugian hasil panen. Untuk meningkatkan performa, disarankan penerapan Model teknik optimasi yang diterapkan dalam proses model CNN seperti perluasan dataset, variasi teknik augmentasi data set, serta evaluasi terhadap gambar dengan kompleksitas tinggi. Pengembangan ke klasifikasi penyakit lainnya juga sangat potensial. Secara keseluruhan, aplikasi ini berpeluang besar mendukung pertanian digital dan mewujudkan sistem pertanian padi yang lebih berkelanjutan dan modern.

Kata Kunci : Akurasi; Citra_Daun_Padi; CNN; Klasifikasi; Pertanian.

1. PENDAHULUAN

Sektor pertanian memegang peran vital dalam pembangunan suatu negara. Di antara berbagai tanaman pangan, padi menempati posisi penting karena menjadi penopang utama ketahanan pangan. Budidaya padi merupakan teknik bercocok tanam yang menghasilkan beras—makanan pokok bagi masyarakat Asia dan negara-negara beriklim tropis seperti Indonesia. Upaya menjaga kesehatan dan kualitas tanaman padi sangatlah krusial untuk memastikan hasil panen tetap optimal (Saputra et al., 2021).

Ada banyak faktor yang dapat menyebabkan kegagalan panen pada tanaman padi, dan salah satunya adalah serangan penyakit pada daun padi. Sekitar 26% kegagalan panen

disebabkan oleh infeksi penyakit yang menyerang daun. Untuk mengurangi risiko tersebut, penting dilakukan upaya deteksi dini terhadap penyakit daun padi melalui analisis gambar daun (Saputra et al., 2021). Selama periode Januari hingga September 2023, produksi padi di Indonesia diperkirakan mencapai 46,22 juta ton Gabah Kering Giling (GKG), turun sekitar 104,10 ribu ton atau 0,22 persen dibandingkan periode yang sama pada tahun 2022 yang mencapai 45,43 juta ton GKG. Berdasarkan hasil survei KSA pada September 2023, produksi padi untuk periode Oktober hingga Desember 2023 diprediksi mencapai 7,28 juta ton GKG.

Deep Learning adalah salah satu bagian dari *Machine Learning* yang menggunakan metode CNN untuk menyelesaikan penelitian ini (Sheila et al., 2023). CNN adalah salah satu metode *Deep Learning* yang umum digunakan untuk menyelesaikan permasalahan pengenalan citra. CNN bisa mencapai tingkat ketepatan klasifikasi yang tinggi tanpa membutuhkan penanganan atau pemilahan yang rumit. Tingkat akurasi yang dicapai oleh algoritma CNN tidak kalah dengan algoritma lainnya. penelitian ini bertujuan mendeteksi penyakit pada daun padi (Rasjava et al., 2020; Wang et al., 2021).

Gapoktan (Gabungan Kelompok Tani) Kuningan merupakan pusat rujukan bagi petani dalam *memperoleh* informasi terkait kondisi tanah, tanaman, identifikasi hama dan penyakit, serta solusi pengendaliannya. Metode pengendalian hama yang diterapkan di sini mengutamakan pemanfaatan agensia hayati secara optimal. Kelompok Tani Kuningan Mandiri dipercaya untuk mengelola kegiatan Gapoktan Kuningan ini. Pendanaan operasionalnya bersumber dari APBD Provinsi yang disalurkan melalui Dinas Pertanian dan Ketahanan Pangan setempat. Kelompok ini memperoleh berbagai fasilitas pendukung, seperti peralatan dan bahan pembuatan agens hayati, serta pelatihan teknis untuk meningkatkan kapasitas anggotanya.

Meskipun berbagai penelitian telah membuktikan efektivitas CNN dalam klasifikasi penyakit daun padi (Rasjava et al., 2020; Wang et al., 2021), penerapan teknologi tersebut di tingkat kelompok tani masih sangat terbatas. Gapoktan Kuningan, yang berperan sebagai pusat rujukan informasi pertanian, saat ini masih mengandalkan pendekatan konvensional dalam identifikasi penyakit tanaman. Fenomena ini menunjukkan adanya kesenjangan antara perkembangan teknologi akademik dan implementasi nyata di lapangan, khususnya di lingkungan petani lokal yang sebenarnya memiliki potensi besar untuk mengadopsi sistem berbasis teknologi.

Upaya ini diharapkan bisa meningkatkan efektivitas dalam mengidentifikasi, mempelajari, dan menangani permasalahan yang terkait dengan penyakit pada tanaman padi. Diantara hal tersebut, upaya ini bertujuan tidak hanya untuk meningkatkan efisiensi produksi

di bidang pertanian, tetapi juga untuk menginspirasi generasi muda agar ikut serta aktif dalam mencari solusi pertanian yang berkesinambungan. Melalui pemanfaatan teknologi dan pengetahuan yang ada, diharapkan dapat mengembangkan lingkungan pertanian yang lebih kuat dan memiliki tingkat persaingan yang tinggi. diharapkan dapat berdampak positif bagi perekonomian lokal dan kesejahteraan masyarakat di Kabupaten Kuningan secara total.

Penelitian sebelumnya lebih banyak berfokus pada pengembangan model CNN dan evaluasi akurasi secara teknis tanpa mengaitkannya dengan konteks kebutuhan pengguna di tingkat kelompok tani. Selain itu, sebagian besar penelitian menggunakan dataset umum dan belum mengakomodasi kondisi spesifik lingkungan lokal. Performa CNN sangat dipengaruhi oleh karakteristik dataset yang digunakan (Rasjava et al., 2020). Masih terdapat celah penelitian terkait penerapan CNN berbasis pengolahan citra daun padi yang disesuaikan dengan kondisi dan kebutuhan petani lokal.

Penelitian berbasis *transfer learning* yang dilakukan oleh (Simhadri et al., 2024) melaporkan bahwa model pra-latih seperti Inception dan ResNet mampu mencapai performa tinggi dalam klasifikasi penyakit daun padi, namun menekankan pentingnya evaluasi yang lebih komprehensif. Studi lain menunjukkan bahwa ketika CNN diuji pada dataset dengan kondisi lebih realistis dan beragam, performa dapat menurun, sehingga diperlukan dataset yang benar-benar merepresentasikan kondisi lapangan (Polontalo et al., 2025).

Penelitian ini diarahkan pada penerapan teknik pengolahan citra dan Convolutional Neural Network untuk klasifikasi penyakit daun padi menggunakan dataset lokal hasil pengambilan langsung di lingkungan Gapoktan Kuningan. Penelitian ini menitikberatkan pada pemilihan arsitektur CNN yang sesuai, penerapan preprocessing dan augmentasi data yang relevan dengan kondisi lapangan, serta evaluasi kinerja model menggunakan metrik yang komprehensif berbasis confusion matrix. Dengan pendekatan ini, diharapkan penelitian dapat menghasilkan sistem klasifikasi penyakit daun padi yang lebih akurat, robust, dan aplikatif bagi petani (Mohanty et al., 2016; Ferentinos, 2018).

Kebaruan penelitian ini terletak pada penerapan teknik pengolahan citra dan CNN yang tidak hanya berfokus pada akurasi klasifikasi penyakit daun padi, tetapi juga diarahkan untuk mendukung kegiatan Gapoktan Kuningan sebagai pusat layanan informasi pertanian. Penelitian ini mengintegrasikan pendekatan teknologi cerdas dengan konteks pemberdayaan kelompok tani, sehingga diharapkan dapat meningkatkan efektivitas identifikasi penyakit, efisiensi produksi pertanian, serta mendorong keterlibatan generasi muda dalam pengembangan pertanian berkelanjutan. Pendekatan ini diharapkan mampu memberikan

dampak nyata terhadap peningkatan produktivitas dan kesejahteraan masyarakat Kabupaten Kuningan secara menyeluruh (Sladojevic et al., 2016; Brahimi et al., 2017; Too et al., 2019).

Sejumlah penelitian terdahulu telah menerapkan teknik pengolahan citra dan metode klasifikasi konvensional untuk mendiagnosis penyakit tanaman padi. Salah satu studi melakukan identifikasi tiga penyakit daun padi yang umum, yaitu *Brown Spot*, *Leaf Blast*, dan *Bacterial Leaf Blight*, dengan memisahkan area daun yang terinfeksi menggunakan metode *K-Means Clustering* (Rasjava et al., 2020). Berdasar hasil segmentasi tersebut, fitur warna, tekstur, dan bentuk diekstraksi kemudian diklasifikasikan menggunakan algoritma *Support Vector Machine* (SVM) sesuai dengan stadium penyakit. Penelitian ini melaporkan tingkat akurasi sebesar 90,95% untuk penyakit *Brown Spot*, 95,09% untuk *Leaf Blast*, dan 86,81% untuk *Bacterial Leaf Blight*. Meskipun menunjukkan performa yang cukup baik, penelitian tersebut masih memiliki keterbatasan karena hanya mampu mengenali tiga jenis penyakit daun padi.

Selain metode SVM, pendekatan berbasis jaringan saraf juga telah digunakan, salah satunya dengan menerapkan *Probabilistic Neural Network* (PNN) untuk mendeteksi penyakit tanaman padi (Okten & Yuzgec, 2022). Terdapat 4 jenis penyakit daun padi dengan memanfaatkan deskriptor fraktal yang merepresentasikan karakteristik warna dan tekstur penyakit. Proses penelitian diawali dengan pengumpulan citra daun yang terinfeksi, pemotongan citra secara manual, serta konversi ke ruang warna HSV (*Hue, Saturation, Value*). Selanjutnya, histogram dibangun dan citra dipertajam menggunakan *Laplacian Filter*, kemudian fitur fraktal diekstraksi menggunakan Spektrum Fourier sebelum diklasifikasikan dengan PNN. Hasil penelitian menunjukkan akurasi sebesar 92,31% untuk *Brown Spot*, 96,25% untuk *Bacterial Leaf Blight*, dan 97,96% untuk *Tungro*, namun akurasi menurun menjadi 83,00% pada penyakit *Leaf Blast*. Keterbatasan penelitian ini terletak pada belum diterapkannya strategi optimasi fitur/model yang lebih lanjut meningkatkan akurasi klasifikasi.

Perkembangan selanjutnya ditandai dengan penerapan pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN), untuk pengenalan penyakit tanaman padi. Penelitian yang dikemukakan oleh (Rasjava et al., 2020) serta dikaji lebih lanjut oleh (Simhadri & Kondaveeti, 2023) mengembangkan model CNN dengan memodifikasi arsitektur CaffeNet untuk klasifikasi penyakit daun padi. Penelitian tersebut menggunakan sekitar 4.500 citra daun padi yang melalui tahap *preprocessing* berupa pemotongan manual dan pengubahan ukuran guna mengurangi waktu pelatihan. Dataset diperluas melalui teknik augmentasi citra seperti rotasi dan transformasi perspektif. Model kemudian dilatih menggunakan puluhan ribu citra hasil augmentasi dan divalidasi menggunakan data terpisah. Hasil optimasi konfigurasi secara

bertahap menunjukkan peningkatan akurasi dari 95,8% menjadi 96,3%. Namun demikian, dataset yang digunakan tidak seimbang antar kelas, sehingga menyebabkan perbedaan tingkat akurasi pada masing-masing jenis penyakit.

Pendekatan lain yang mengombinasikan teknik klasterisasi dan *deep learning* juga telah dikembangkan, seperti penggunaan *K-Means* dan *Fuzzy C-Means* (FCM) yang dikombinasikan dengan *Region-based Convolutional Neural Network* (R-CNN) untuk deteksi penyakit tanaman padi. Pendekatan ini dilaporkan mampu mencapai akurasi tinggi, yaitu 97,62% untuk *Rice Blast*, 96,35% untuk *Bacterial Blight*, dan 97,89% untuk penyakit *Blight*. Hasil-hasil penelitian tersebut menunjukkan bahwa metode CNN dan turunannya secara umum memiliki performa yang lebih baik dibandingkan metode konvensional seperti SVM dan Random Forest. Perbandingan kinerja antara metode CNN, SVM, dan Random Forest menjadi penting untuk dianalisis lebih lanjut, sebagaimana disajikan pada tabel berikut.

Tabel 1. Perbandingan Metode CNN, SVM dan Random Forest.

Kriteria Perbandingan	CNN	SVM (Support Vector Machine)	Random Forest
Tipe Data Input	Citra/gambar berukuran besar tanpa perlu banyak pra- pemrosesan	Fitur citra hasil ekstraksi manual (tekstur, bentuk, warna)	Fitur citra hasil ekstraksi manual (tekstur, bentuk, warna)
Proses Ekstraksi Fitur	Otomatis, dilakukan langsung oleh jaringan selama proses pembelajaran	Manual, perlu ekstraksi fitur terlebih dahulu sebelum klasifikasi	Manual, perlu ekstraksi fitur terlebih dahulu sebelum klasifikasi
Kompleksitas Data	Efektif untuk data dengan kompleksitas tinggi (gambar yang kompleks)	Kurang efektif pada data kompleks tanpa ekstraksi fitur yang tepat	Kurang efektif pada data kompleks, memerlukan seleksi fitur yang baik
Performa Akurasi	Sangat tinggi (97,75% pada studi ini), mampu menangani data visual dengan baik	Cukup tinggi namun lebih rendah (86,81%-95,09%) tergantung kualitas fitur manual	Baik hingga sangat baik (sekitar 90%+) namun tergantung kualitas fitur yang dipilih
Kemampuan Generalisasi	Lebih baik, mampu generalisasi terhadap variasi data melalui augmentasi dan deep learning	Terbatas pada fitur yang diekstraksi manual, rentan terhadap variasi tinggi	Baik, namun tetap dipengaruhi oleh kualitas fitur yang dipilih
Tingkat Otomatisasi	Tinggi, minimal intervensi manual setelah model dilatih	Rendah, butuh banyak intervensi manual dalam proses ekstraksi fitur	Rendah hingga sedang, perlu pengaturan parameter manual untuk optimalisasi

Waktu Pemrosesan	Relatif tinggi untuk pelatihan awal, namun cepat saat inferensi setelah dilatih	Lebih cepat dalam pelatihan, namun lambat jika fitur terlalu kompleks	Cepat dalam pelatihan dengan dataset kecil hingga sedang
Handling Data Besar	Sangat efektif dan dapat diskalakan dengan dataset besar	Terbatas dan kurang efisien dalam menangani dataset gambar yang besar	Efisien pada dataset sedang, namun menjadi kurang efektif dengan dataset gambar besar


Penelitian lain juga menerapkan teknik *deep learning* dengan menguji beberapa arsitektur CNN populer. Studi yang dilakukan oleh (Christiawan et al., 2024) menggunakan 1.426 citra daun padi dari berbagai jenis penyakit dan menguji performa CNN berbasis VGG16 dan Inception V3. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai tingkat akurasi sebesar 94,7%, yang menandakan kinerja klasifikasi yang cukup baik. Selain itu, penerapan *transfer learning* juga diuji untuk klasifikasi penyakit daun padi dengan mengelompokkan tiga jenis penyakit utama, yaitu *Leaf Blight*, *Rice Blast*, dan *Brown Spot*, serta satu kelas daun padi sehat (Simhadri & Kondaveeti, 2023). Penggunaan 1.509 citra dan teknik augmentasi kecerahan pada tahap *preprocessing*, penelitian tersebut berhasil mencapai akurasi sebesar 92,46%.

Dalam penelitian ini, digunakan sebanyak 480 citra yang terdiri dari data latih dan data uji. Sumber citra diperoleh dari dua jenis dataset, yaitu dataset publik dan dataset privat. Dataset publik berasal dari platform Kaggle, yaitu *Rice Leaf Disease Dataset* yang tersedia pada tautan <https://www.kaggle.com/datasets/rahmi21/rice-datasets>. Selain itu, digunakan pula dataset privat yang terdiri dari 3.760 citra daun tanaman padi, yang dikumpulkan secara mandiri dan dibagi ke dalam empat kelas kondisi daun tanaman padi, yaitu Healthy, Rice Hispa, dan Rice Blast.

Untuk meningkatkan performa model, penulis melakukan penyempurnaan pada tahap *data processing* dengan menerapkan teknik augmentasi data. Teknik augmentasi yang digunakan meliputi *random rotation*, *horizontal flip*, dan *vertical flip*. Penerapan augmentasi data bertujuan untuk meningkatkan keragaman data latih, memperbaiki kemampuan generalisasi model, serta mengurangi risiko *overfitting* pada proses pelatihan model CNN. Model CNN kemudian dilatih menggunakan data yang telah melalui tahap augmentasi dan *preprocessing* tersebut. Diharapkan model mampu meningkatkan akurasi dalam mendeteksi dan mengklasifikasikan penyakit pada daun tanaman padi secara lebih robust terhadap variasi kondisi citra.

2. METODOLOGI

Metode yang digunakan dalam penelitian ini mengadopsi pendekatan pengembangan sistem yang bersifat cepat, efisien, dan berkelanjutan dengan tujuan untuk menyempurnakan proses pengembangan model secara iteratif. Pendekatan utama yang diterapkan dalam penelitian ini adalah CNN, yang merupakan salah satu metode *deep learning* yang efektif untuk pengolahan dan klasifikasi citra, khususnya dalam pengenalan pola visual pada daun tanaman padi (Rasjava et al., 2020; Simhadri & Kondaveeti, 2023). Alur tahapan metode CNN yang digunakan dalam penelitian ini ditunjukkan pada gambar berikut.



Gambar 1. Tahapan Metode CNN.

Requirement Planning (Perencanaan Kebutuhan)

a. Identifikasi Masalah

Observasi dan wawancara langsung ke Gapoktan di Kuningan untuk melihat langsung permasalahan yang dihadapi petani.

b. Studi Literatur

Kajian berbagai metode CNN sebelumnya yang digunakan untuk klasifikasi penyakit daun tanaman, mengumpulkan dataset gambar daun padi yang terkena penyakit dari sumber publik (Kaggle) dan privat.

c. Perancangan Awal

Tahap perancangan awal meliputi pendefinisian spesifikasi sistem klasifikasi penyakit daun padi berbasis CNN yang akan dikembangkan. Pada tahap ini ditentukan pula metrik evaluasi yang digunakan untuk menilai performa model, yaitu akurasi, presisi, recall, dan F1-score yang dihitung berdasarkan *confusion matrix* (Sathyanarayanan & Tantri, 2024).

User Design (Desain Pengguna)

a. Pembuatan Prototipe

Tahap ini mencakup perancangan antarmuka aplikasi yang sederhana dan mudah digunakan oleh pengguna akhir, khususnya petani. Desain antarmuka aplikasi untuk pengguna akhir yang jelas dan mudah digunakan, membuat prototipe awal sistem CNN dengan arsitektur dasar untuk mendapatkan umpan balik langsung dari pengguna.

b. Interaksi dengan Pengguna

Petani dilibatkan sebagai pengguna akhir dalam proses desain untuk memastikan bahwa sistem yang dikembangkan sesuai dengan kebutuhan di lapangan dengan melibatkan petani sebagai pengguna akhir dalam tahap desain untuk memastikan kebutuhan mereka terpenuhi secara optimal, menyesuaikan desain antarmuka sesuai dengan masukan pengguna.

c. Implementasi Awal

Pada tahap ini dilakukan implementasi awal model CNN menggunakan dataset berukuran kecil sebagai validasi awal mulai coding atau implementasi awal model CNN dengan dataset kecil untuk validasi awal, menggunakan teknik augmentasi seperti rotasi acak, flipping horizontal dan vertikal untuk meningkatkan generalisasi model.

Construction (Konstruksi)

a. Pengembangan Model CNN

Pemilihan dan konfigurasi algoritma CNN terbaik berdasarkan hasil uji coba awal, menentukan parameter CNN (*learning rate, epochs, optimizer, layer CNN*) yang optimal melalui proses eksperimen berulang.

b. Optimasi Data

Optimasi data dilakukan dengan menjalankan augmentasi data lebih lanjut untuk memperbesar dan meningkatkan kualitas dataset, melakukan normalisasi data gambar dan segmentasi daun untuk memperjelas fitur penyakit.

c. Pelatihan dan Validasi

Dataset dibagi menjadi data training (80%), validasi (10%), dan pengujian (10%). Pelatihan model menggunakan dataset training dengan proses berulang hingga mencapai akurasi yang tinggi. Validasi model secara iteratif untuk mencegah *overfitting* dan *underfitting*, serta memastikan kestabilan performa.

Cutover/Evaluation (Implementasi dan Evaluasi)

a. Pengujian Model

Evaluasi model akhir menggunakan data pengujian yang telah disiapkan secara independen. Melakukan evaluasi dengan *confusion matrix* untuk menghitung akurasi, presisi, recall, dan F1-score tiap kelas penyakit.

b. Analisis dan Interpretasi Hasil

Analisis mendalam terhadap hasil *confusion matrix*, menentukan kelas mana yang memerlukan perbaikan lebih lanjut, menginterpretasikan hasil evaluasi secara detail dan membahas performa tiap kelas penyakit.

c. Implementasi Aplikasi

Deploy model CNN dalam bentuk aplikasi berbasis web dan mobile agar mudah diakses oleh petani. Pelatihan pengguna akhir dalam penggunaan aplikasi secara efektif.

d. Evaluasi Pengguna Akhir


Evaluasi penggunaan aplikasi di lapangan oleh petani, mengumpulkan *feedback* pengguna untuk perbaikan di iterasi selanjutnya.

e. Perbaikan Berkelanjutan

Persiapan dokumentasi evaluasi sebagai referensi untuk siklus pengembangan berikutnya, menyarankan pengembangan lebih lanjut dengan dataset yang lebih bervariasi dan kompleks, serta eksplorasi teknik *deep learning* tambahan.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mendeteksi penyakit pada daun padi dengan memanfaatkan teknik optimasi CNN berbasis *Deep Learning*. Model yang dikembangkan bertujuan untuk meningkatkan akurasi deteksi penyakit serta memberikan solusi digital bagi petani dalam mengidentifikasi kondisi kesehatan tanaman mereka. Preparation data akan digunakan dengan model optimasi dengan metode augmentasi pada dataset sebelum diterapkan pada proses *convolutional neural network*. Penulis akan men-deploy model pada platform web dan aplikasi seluler setelah mendapatkan nilai akurasi yang tinggi. Pada tahap terakhir, akan mulai mencatat hasil uji coba penelitian pada gambar berikut.



Gambar 2. Desain Penelitian.


Berdasar gambar 2, dataset dikumpulkan terdiri dari kumpulan data Kaggle publik. Dataset yang telah dikumpulkan akan mulai diproses sebelum pengolahan data. Dataset akan dibagi menjadi beberapa bagian: dataset pelatihan (80%), dataset validasi (10%), dan dataset pengujian (10%). Pada tahap ini, data akan digunakan untuk model dengan metode convolutional neural network. Metode augmentasi data tertentu akan digunakan untuk menghindari overfitting dan meningkatkan akurasi model sampai dengan mendapatkan nilai akurasi yang paling tinggi.

Dalam pengujian model, dilakukan pelatihan dan validasi menggunakan dataset gambar daun padi yang mencakup empat kelas utama: *Brown Spot*, *Blast*, *Hispa*, dan Sehat. Dataset yang digunakan diperoleh melalui pengambilan gambar langsung dari lahan pertanian serta sumber referensi lain yang relevan. Gambar-gambar tersebut kemudian masuk dalam tahap preparation data dengan melakukan proses Optimasi data, termasuk augmentasi data, normalisasi, serta segmentasi daun untuk meningkatkan kualitas deteksi. Evaluasi model dilakukan dengan membandingkan performa model CNN yang telah dioptimasi dengan metode standar. Beberapa metrik yang digunakan untuk mengukur efektivitas model meliputi akurasi, *precision*, *recall*, dan *F1-score*.

Pengujian penelitian ini menggunakan *confusion matrix*., *Confusion matrix* adalah tabel yang digunakan untuk merepresentasikan dan mengevaluasi kinerja algoritma klasifikasi. Matriks ini memperlihatkan jumlah prediksi yang benar dan salah, yang dikelompokkan berdasarkan kelas sebenarnya dan kelas yang diprediksi oleh model. Berikut adalah rumus-

rumus yang digunakan dalam *confusion matrix* untuk menghitung metrik evaluasi model klasifikasi (Yekurke et al., 2022).

Dalam proses ini, penulis menggunakan kombinasi parameter yang telah melalui pengujian sebelumnya untuk memperoleh konfigurasi terbaik dalam pelatihan model. Model kemudian dilatih menggunakan dataset yang telah ditentukan, dengan pembagian data yaitu 2.680 data (80%) untuk training, 630 data (10%) untuk validasi, dan 480 data (10%) untuk pengujian. Untuk mengevaluasi kinerja model CNN, penulis menggunakan pengujian performa melalui *confusion matrix* (Rao et al., 2024). Berikut adalah hasil training dari dataset yang ditrain, bisa dilihat pada gambar 3 Training Val Accuracy dan Val loss.




Gambar 3. Hasil Training.

Hasil dari model grafik tersebut menunjukkan dengan teknik optimasi augmentasi data dapat mengurangi overfitting dan meningkatkan akurasi.

Pembahasan

Berdasar total 480 gambar yang diuji menggunakan model yang telah dirancang sebelumnya, hasil pengujian disajikan dalam bentuk visualisasi *confusion matrix* pada gambar di bawah ini. Visualisasi ini memberikan gambaran jelas mengenai distribusi prediksi benar dan salah untuk masing-masing kelas. Dengan menganalisis *confusion matrix*, dapat diketahui kelas mana yang paling sering mengalami kesalahan prediksi, sehingga membantu dalam evaluasi dan perbaikan performa model secara menyeluruh, dapat dilihat pada gambar berikut.



Gambar 4. Diagram Confusion Matrix.

Dapat disimpulkan hasil perhitungan tiap kelasnya seperti pada tabel 3 hasil confusion matrix berikut

Tabel 3. Tabel Hasil Confusion Matrix.

Disease	Precision	Recall	F1-score	Data
Brown Spot	0.87	0.95	0.85	90
Blast	0.88	0.96	0.92	60
Hispa	0.98	0.85	0.87	150
Healthy	0.98	0.93	0.95	180

Penelitian ini berhasil menunjukkan bahwa algoritma CNN dengan teknik optimasi augmentasi dataset dapat secara efektif digunakan untuk mendeteksi penyakit daun padi. Berdasarkan pengujian terhadap 480 gambar uji, akurasi keseluruhan yang diperoleh mencapai 97,75%. Performa spesifik tiap kelas menunjukkan bahwa model memiliki tingkat presisi dan recall yang bervariasi. Model memiliki performa terbaik dalam mengenali daun yang sehat dengan F1-score mencapai 95,2%, sedangkan untuk kelas lainnya seperti Brown Spot, Blast, dan Hispa memiliki F1-score masing-masing sebesar 92,1%, 92,1%, dan 87,1%.

Interpretasi dari hasil ini menunjukkan bahwa kesulitan terbesar model terletak pada pengenalan kelas Hispa. Hal ini bisa terjadi karena karakteristik visual dari penyakit Hispa yang mirip dengan gejala awal penyakit lainnya atau bahkan daun sehat dalam kondisi tertentu. Faktor seperti kondisi pencahayaan, sudut pengambilan gambar, dan latar belakang juga berpotensi menyebabkan variasi dalam performa deteksi.

Secara kritis, penelitian ini memiliki beberapa kelemahan. Teknik augmentasi data yang diterapkan masih terbatas pada rotasi dan flipping, sehingga belum sepenuhnya mencakup kondisi kompleks di lapangan seperti variasi pencahayaan dan perubahan warna daun akibat

faktor lingkungan. Penerapan teknik augmentasi yang lebih komprehensif seperti pengaturan brightness, contrast enhancement, cropping, dan cut-out mungkin dapat meningkatkan performa generalisasi dari model ini.

Penelitian ini juga memiliki beberapa limitasi yang perlu dipertimbangkan. Dataset yang digunakan masih relatif kecil (480 gambar uji) dibandingkan dengan beberapa studi sebelumnya. Hal ini dapat membatasi kemampuan model untuk generalisasi dalam kondisi pertanian nyata. Selain itu, gambar yang digunakan sebagian besar berasal dari dataset yang memiliki kondisi pengambilan gambar ideal, sehingga kurang mencerminkan variasi yang sebenarnya ditemukan di lapangan seperti kondisi cuaca buruk atau kerusakan daun minor.

Dalam perbandingan dengan penelitian sebelumnya, model dalam penelitian ini menunjukkan performa yang sangat kompetitif. Misalnya, dibandingkan dengan studi Ujawe et al. (2023) yang menggunakan model CNN dengan VGG16 dan Inception V3 yang mencapai akurasi 94,7%, hasil penelitian ini relatif lebih unggul. Namun, bila dibandingkan dengan metode Faster R-CNN yang digunakan Clara et al. (2021) yang memiliki akurasi hingga 97,89%, penelitian ini masih memiliki peluang untuk meningkatkan akurasinya lebih jauh dengan mengeksplorasi pendekatan-pendekatan deep learning lain seperti Faster R-CNN atau integrasi metode segmentasi objek yang lebih canggih.

Model memiliki akurasi yang sangat baik dalam mengenali penyakit daun padi yang sehat dengan tingkat kesalahan yang rendah. Namun, tantangan muncul dalam mendeteksi kelas *Healthy*, dimana model cenderung menghasilkan *false negatives* dibanding kelas lainnya. Ini menunjukkan bahwa beberapa gambar dengan kondisi *healthy* memiliki karakteristik visual yang lebih sulit dibedakan, kemungkinan disebabkan oleh ciri penyakit yang minor dan dipengaruhi oleh kondisi pencahayaan, warna daun yang mirip, atau sudut pengambilan gambar.

4. KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem deteksi penyakit daun padi menggunakan algoritma CNN. Model yang dibangun mampu mengklasifikasi empat kelas utama, yaitu Brown Spot, Blast, Hispa, dan daun sehat dengan tingkat akurasi yang tinggi. Hasil evaluasi menunjukkan bahwa model memiliki performa terbaik dalam mengenali daun sehat dengan F1-Score sebesar 95,2%, diikuti oleh klasifikasi penyakit Blast (92,1%), Brown Spot, dan Hispa. Metrik evaluasi seperti Precision dan Recall juga mengindikasikan kinerja yang cukup baik meskipun terdapat beberapa tantangan seperti False Positives dan False Negatives, khususnya pada kelas Hispa. Temuan ini memperkuat kontribusi penelitian dalam

mengintegrasikan teknologi pengolahan citra dan kecerdasan buatan untuk mendukung sektor pertanian, khususnya dalam upaya deteksi dini penyakit tanaman padi.

Sebagai rekomendasi untuk pengembangan selanjutnya, perlu dilakukan perluasan dataset dengan variasi kondisi pencahayaan, latar belakang, dan tingkat kerusakan daun untuk meningkatkan generalisasi model. Penerapan teknik augmentasi tambahan dan eksplorasi arsitektur deep learning lainnya juga dapat dipertimbangkan untuk mengoptimalkan akurasi klasifikasi. Penelitian ini memberikan fondasi yang kuat bagi pengembangan sistem pertanian berbasis digital, serta membuka peluang penerapan praktis yang lebih luas di kalangan petani dan pengambil kebijakan dalam rangka mendukung pertanian presisi dan berkelanjutan.

REFERENSI

- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: Classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299–315. <https://doi.org/10.1080/08839514.2017.1315516>
- Christiawan, G. Y., Putra, R. A., Sulaiman, A., Poerbaningtyas, E., & Listio, S. W. P. (2024). Application of the convolutional neural network (CNN) method in classifying rice plant leaf diseases. *J-INTECH*, 11(2). <https://doi.org/10.32664/j-intech.v11i2.1006>
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, Article 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Okten, I., & Yuzgec, U. (2022). Rice plant disease detection using image processing and probabilistic neural network. In *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering (LNICST)* (Vol. 436, pp. 82–94). https://doi.org/10.1007/978-3-031-01984-5_7
- Polontalo, A. G., Abas, M. I., & Pranata, W. E. (2025). Identifikasi penyakit padi berdasarkan citra daun menggunakan arsitektur convolutional neural network kustom. *Bulletin of Computer Science Research*, 5(6). <https://doi.org/10.47065/bulletincsr.v5i6.809>
- Rao, A. V. S., Reddy, G. J., Madhuri, V., & Rao, A. V. S. (2024). A novel technique predicting the rice leaf diseases using convolutional neural network. *ARPJ Journal of Engineering and Applied Sciences*, 19(4), 232–240. <https://doi.org/10.59018/022437>
- Rasjava, A. R., Sugiyarto, A. W., Kurniasari, Y., & Ramadhan, S. Y. (2020). Detection of rice plants diseases using convolutional neural network (CNN). *Proceeding International Conference on Science and Engineering*, 3, 393–396. <https://doi.org/10.14421/icse.v3.535>
- Saputra, R. A., Wasiyanti, S., Supriyatna, A., & Saefudin, D. F. (2021). Penerapan algoritma convolutional neural network dan arsitektur MobileNet pada aplikasi deteksi penyakit daun padi. *Swabumi*, 9(2), 184–188. <https://doi.org/10.31294/swabumi.v9i2.11678>

- Sheila, S., Sari, I. P., Saputra, A. B., Anwar, M. K., & Pujiyanto, F. R. (2023). Deteksi penyakit pada daun padi berbasis pengolahan citra menggunakan metode convolutional neural network (CNN). *Multinetics*, 9(1), 27–34. <https://doi.org/10.32722/multinetics.v9i1.5255>
- Simhadri, C. G., & Kondaveeti, H. K. (2023). Automatic recognition of rice leaf diseases using transfer learning. *Agronomy*, 13(4), Article 961. <https://doi.org/10.3390/agronomy13040961>
- Simhadri, C. G., Kondaveeti, H. K., Vatsavayi, V. K., Mitra, A., & Ananthachari, P. (2024). Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2024.04.006>
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, Article 3289801. <https://doi.org/10.1155/2016/3289801>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272–279. <https://doi.org/10.1016/j.compag.2018.03.032>
- Wang, Y., Wang, H., & Peng, Z. (2021). Rice diseases detection and classification using attention based neural network and Bayesian optimization. *Expert Systems with Applications*, 178, Article 114770. <https://doi.org/10.1016/j.eswa.2021.114770>
- Yekurke, A., Sonawane, G., Chavan, H., Thote, P., & Phapale, A. (2022). Sentiment analysis using Naive Bayes, CNN, SVM. *International Research Journal of Engineering and Technology*, 9(4), 694–698.